

Uso de Geotecnologias para a detecção de Sistemas Integrados de Produção Agropecuária: Uma contribuição para o Monitoramento da Agricultura de Baixa Emissão de Carbono

Patrick Calvano Kuchler ^{1,3}
Margareth Simões ^{1,2}
Rodrigo Ferraz ²
Agnès Bégué ³

¹ UERJ/FEN/DESC/PPGMA - UERJ
Rio de Janeiro, RJ, Brasil
geocalvano@gmail.com

² EMBRAPA Solos
Jardim botânico, Rio de Janeiro, RJ, Brasil
{margareth.simoese, rodrigo.demonte}@embrapa.br

³ CIRAD.
Montpellier, Hérault, França
{agnes.begue, patrick.kuchler}@cirad.fr

Resumo. A implementação dos Sistemas Integrados de produção agropecuária (SI), ou seja, a integração lavoura-pecuária-floresta (ILPFs), constitui uma importante estratégia de intensificação agrícola sustentável para o Brasil. Estados, como Mato Grosso (MT), tradicionalmente grandes produtores agrícolas já vem adotando esta estratégia e potencializando a sua capacidade produtiva. O Governo Federal vem, desde 2009, promovendo a disseminação e adoção dos sistemas integrados, entretanto ainda não existe uma metodologia de monitoramento desta tendência. Nossa hipótese é que técnicas de classificação Random Forest (RF) aplicadas a Séries Temporais (ST) do satélite MODIS sejam capazes de detectar determinados SI no MT. Para isso, avaliamos a acurácia do RF aplicado a ST de 16 dias de NDVI do MODIS MOD13Q1 para os anos de 2012 a 2016 em uma área no norte do MT. As ST foram utilizadas de forma original e processadas. Como processamento, foi utilizada a técnica baseada em Savitsky golay para filtragem e suavização e posteriormente geradas 11 métricas fenológicas para cada ano. Dois modelos RF foram testados: (i) utilizando as 11 métricas fenológicas (ii) utilizando as métricas e a série original. O índice kappa para (i) foi de 0,63 sendo que 9 apresentam potencial discriminatório, já o resultado de (ii) foi de 0,84 onde apenas 01 métrica obteve importância significativa para a discriminação. Nossos resultados apontam que a utilização da técnica de classificação RF em abordagem multitemporal com dados MODIS tem grande potencial para compor uma metodologia de monitoramento de alguns tipos de SI. Sendo a combinação das séries originais com as métricas apresentaram ganhos não muito expressivos.

Palavras-chave: sensoriamento remoto, séries-temporais, random forest, Mato Grosso, sistemas integrados.

Abstract. The implementation of Integrated Systems (IS), ie the combination of agricultural, livestock and / or forestry activities in the same area, is considered as an important sustainable agricultural intensification strategy in Brazil, particularly in Mato Grosso state (MT). The Federal Government has been promoting the dissemination of this practice since 2009, but there is still no methodology to follow up on this initiative. Our hypothesis is that Random Forest (RF) classification techniques applied to the MODIS satellite's Time Series (TS) are able to detect certain ISs in TS. For this, we evaluated the accuracy of the RF applied to the 16 day TS of NDVI of MODIS MOD13Q1 for the years 2012 to 2016 in an area in the north of the MT. The TS were used in an original way and processed. As processing, the technique based on Savitsky golay was used for filtering and smoothing and later 11 phenological metrics were generated per year. Two RF models were tested: (i) using the 11 metrics (ii) using the metrics and the original series. The kappa index for (i) was 0.63, were 9 of then having discriminatory potential; the result of (ii) was 0.84 where only 01 metric was significant for discrimination. Our results indicate that the use of the RF classification technique in a multitemporal approach with MODIS data has great potential to compose a monitoring methodology of some type of IS. The combination of the original series with the metrics have not presented an expressive gain.

Keywords: remote sensing, time series, random forest, Mato Grosso, integrated systems.

1. Introdução

Atualmente o Brasil é uma das maiores potências agrícolas no mercado mundial, exercendo papel significativo no suprimento atual e das próximas décadas na demanda global de alimentos e energia (Godfray et al., 2010; Arvor et al., 2012). A expansão de áreas agropecuárias se desenvolveu e ainda se desenvolve em um padrão de abandono de áreas em estágio de degradação e abertura de novas áreas, exercendo pressão sobre recursos florestais. Esta dinâmica fez com que o Brasil entrasse como 6º maior país emissor de Gases de Efeito Estufa (GEE) reportado na 17ª Conferência das Partes (COP-17). Nesta mesma conferência foi apontado que 50% das emissões globais eram provenientes de 5 países, representando cerca de 75% das emissões provenientes da geração de energia e processos industriais, enquanto o Brasil representava quase 80% de suas emissões relativas a agricultura e mudança do uso da terra e florestas (MCTI, 2014).

Em um esforço para evitar o desmatamento, otimizar o uso da terra e recuperar pastagens degradadas, o governo brasileiro vem adotando medidas para direcionar a expansão das pastagens e culturas para áreas já desmatadas e promover práticas agrícolas que possam intensificar a produção de forma menos agressiva ao meio ambiente. Estas medidas são fruto de um compromisso assumido voluntariamente de redução da emissão de GEE entre 36,1% e 38,9% até 2020 durante a COP15 ocorrida em Copenhague no ano de 2009. Neste momento, foram propostas algumas ações, dentre as quais, na área agrícola, a promoção da agricultura de baixo carbono, dando origem ao plano setorial de mitigação das mudanças climáticas para a agricultura, o chamado plano ABC. Os Sistemas Integrados (SI) merecem ser destacados neste contexto como uma estratégia muito promissora para atingir as metas firmadas. Combinando culturas, pecuária e / ou silvicultura nas mesmas áreas, eles podem ser capazes de aumentar a fertilidade e a matéria orgânica contida no solo, que favorece a produção de biomassa (Bungenstab, 2012; Carvalho et al., 2014). Esse aumento na produtividade total do sistema representa uma vantagem direta para a sociedade em geral e para os agricultores, quando refletida em maior retorno econômico e conservação do solo a longo prazo. Os SI podem ser divididos em dois grandes grupos: A integração Lavoura, Pecuária e Floresta (iLPF) e a integração Lavoura e Pecuária (iLP). O iLPF pode ser caracterizado pelo sistema consorciado entre lavoura, floresta comercial e pastagem. A floresta é plantada em linhas e entre elas são rotacionadas as culturas e a pastagem. O iLP é baseado em consórcio, sucessão de culturas e/ou rotação, onde sempre terá que haver o elemento pastagem. Neste tipo de sistema, a pastagem é intercalada com a cultura, ou vice-versa em uma abordagem intra-anual, inter-anual ou ambas, apresentando uma grande complexidade em termos de tipos de arranjos possíveis. Diversos

produtores rurais já estão se adequando nestas iniciativas e contam com linhas de crédito específicos.

Um ponto em destaque no plano ABC se refere ao desafio de criar mecanismos efetivos para monitorar e acompanhar o desenvolvimento dessas ações propostas, mecanismos estes, que sejam capazes de comprovar o cumprimento dos compromissos firmados (MAPA, 2011).

Acredita-se que técnicas de SR em abordagem multitemporal sejam capazes de detectar SI no MT, afim de compor uma metodologia de monitoramento da implantação destes. Desta forma, este estudo pretende contribuir com o posto acima, na estratégia do monitoramento da eficácia do programa através do mapeamento das áreas produtivas utilizando técnicas inovadoras de SR e imagens multitemporais.

2. Objetivos

O objetivo geral deste trabalho compreende em avaliar o potencial da técnica de classificação *random forest* em abordagem multitemporal de índices de vegetação do MODIS na detecção de sistemas iLP em uma área no norte do estado do Mato Grosso, afim de compor uma metodologia de monitoramento destas práticas.

Como objetivos específicos, (i) avaliar o potencial de métricas fenológicas para compor uma classificação RF de áreas com iLP. (ii) Avaliar um modelo RF com as métricas fenológicas e as séries originais para a detecção dos sistemas iLP.

3. Material e Métodos

3.1 Área de Estudos

Mato Grosso (MT) é um estado brasileiro dentro da “Arco do desmatamento”, onde a agricultura está se expandindo rapidamente. Ao mesmo tempo, os sistemas locais de produção pecuária são altamente intensivos e com baixas taxas de lotação, que contribuem para aumento da pressão global da terra e mudança do uso da terra. Considerando que Mato Grosso é o principal produtor de gado e soja do país e fica adjacente à porção mais densa da floresta amazônica, a adoção de SI neste estado poderia ajudar a alcançar o desenvolvimento de tecnologias mais eficientes e sustentáveis. Foi selecionada uma área na porção norte do estado para testar a metodologia proposta. O local foi escolhido, devido a disponibilidade de dados. A figura 1 apresenta a localização da área de estudo.



Figura 1 – Localização da área de estudo.

3.2 Séries Temporais

O caráter sinóptico, multiespectral e repetitivo dos satélites faz com que o sensoriamento remoto tenha grande potencial para o mapeamento de áreas agrícolas, principalmente em países de grandes dimensões como o Brasil. Correntes atuais assumem que para o monitoramento da agricultura por SR, uma única imagem de satélite, de uma única data, não fornece informações espectrais suficientes para identificar culturas plantadas em uma determinada estação, por este motivo, séries temporais de dados de Índices de Vegetação são utilizados para o mapeamento de sistemas agrícolas. Este tipo de abordagem utilizando dados do sensor MODIS estão sendo testadas no Brasil e em particular no MT para o mapeamento de culturas anuais. Existe um número considerável de estudos já realizados da dinâmica agrícola brasileira no MT por SR utilizando sensores óticos. Spera et al. (2014) usam o SR para examinar padrões de terra cultivável para a expansão agrícola no estado na janela temporal de 2001 a 2011. Eles usaram uma série temporal de EVI do MODIS, com um algoritmo de árvore de decisão. Foram identificados dados de cultivos específicos para mapear as terras cultiváveis de grande escala em cinco classes: soja, algodão, soja-milho, soja-algodão, e culturas irrigadas. O artigo descreve como aumentar a expansão depende dos atributos da terra como solo, clima e topografia. Os autores descobriram que as áreas mais adequadas para a expansão de terras agrícolas no MT foram ocupadas em 2006, os agricultores aumentaram os sistemas de cultivo duplo.

Arvor et al. (2011) também utilizou a série temporal MODIS EVI para identificar cinco classes de culturas: culturas de soja, milho e algodão plantadas em sistemas de cultivo simples ou duplo. Eles assumem que o milho só é plantado em consórcio com soja. Os autores coletaram dados de campo em 50 fazendas em um total de 1920 parcelas entre os anos de 2005-2006 e 2006-2007. O estudo usa um método de classificação em duas etapas, uma máscara de terra cultivada e, em seguida, discriminando as variedades de culturas de interesse dentro da máscara. Os autores aplicam uma segmentação para produzir resultados mais homogêneos. A precisão relatada é de 85% para a máscara de agricultura e 74% para a classificação, usando dados de validação não incluídos no conjunto de treinamento.

Para descrever a dinâmica espacial da produção agrícola no MT de 2001 a 2014, Kastens et al. (2017) usam a série temporal MODIS NDVI. Eles utilizam dados de referência de campo de 2009 a 2016 para criar uma base de aprendizagem do classificador *random forest*. A precisão relatada foi de 79% para distinguir classes de culturas (soja-pousio, algodão em pousio, soja-algodão e soja). A classe da cultura da soja inclui milho, painço, sorgo e girassol, que eles afirmaram que não poderiam distinguir bem.

Chen et al. (2018) desenvolveram uma metodologia para identificar tipos de culturas, incluindo soja, algodão e milho em sistemas: soja-milho, soja-algodão, soja-pasto, soja-pousio, pousio-algodão e cultura única no MT. Foram utilizados dados NDVI do MODIS que passaram por processo de filtragem e suavização para minimizar efeitos atmosféricos como nuvens. Foram extraídas métricas fenológicas das séries temporais pré-processadas e posteriormente foi utilizado um classificador de árvore de decisão para o mapeamento nos anos de 2015 e 2016. Para a avaliação da classificação foram utilizados dados de campo realizado em 2016, interpretação de imagem Landsat de 2016 e dados secundários de tipos de culturas em 2015. Eles alcançaram uma acurácia de 90% para áreas cultivadas, 73% para padrões de culturas e 86% para tipos de culturas. Foi feito um ajustamento para simplificar as classes em áreas cultivadas com 94% de acurácia, soja com 94%, milho com 88% e algodão com 88%. O autor apresenta a grande dificuldade de diferenciar pasto das culturas de algodão, milho, milheto e cana-de-açúcar, apontando grande mistura espectral, que ocasiona em perfis similares. Por este motivo, o ajustamento que resultou na maior acurácia apontada, foi alcançada pela fusão das culturas Soja-Milho, Soja-Algodão, Soja-Pousio, Soja-Pasto e Soja em cultura única como uma única classe chamada Soja.

Existem também grandes programas contínuos de monitoramento com base governamental, como é o caso do sistema PRODES do Instituto Nacional do Brasil para pesquisa espacial (INPE) que produz uma máscara florestal / não florestal (Hansen et al., 2008). O INPE, junto com a EMBRAPA, produziu o TerraClass, um mapa da mudança da cobertura no bioma Amazônia (ALMEIDA et al., 2016). O produto TerraClass produz uma máscara de áreas de cultivo, e não distingue entre as diferentes culturas para os anos de 2010, 2012 e 2014.

Foram publicados no mês de novembro de 2017 pelo portal *Pangaea* dados do mapeamento de tipos de cultura entre os anos de 2001 e 2016 no estado do MT com as seguintes classes e seus respectivos coeficientes de acurácia: Cerrado (99%), Pousio-Algodão (100%), Floresta (99%), Pasto (95%), Soja-Milho (87%), Soja-Algodão (99%), Soja-Pousio (100%), Soja-Milheto (84%), e soja Girasol (85%) (CÂMARA et al., 2017).

3.3 Dados e processamentos utilizados

Foi utilizada uma série temporal com intervalo de 16 dias do índice de vegetação de diferença normalizada (NDVI, sigla em inglês) do MODIS MOD13Q1 para os anos de 2012 a 2016 totalizando 155 imagens.

Jönsson e Eklundh (2004) desenvolveram o programa TIMESAT que tem com o objetivo de extrair informações sobre a fenologia da vegetação com base na sazonalidade através de dados de IV oriundos de produtos obtidos pelo SR. Todas informações extraídas por este programa são de séries temporais, que inicialmente devem passar pelo pré-processamento de filtragem e suavização das curvas. Após este procedimento de suavização, o TIMESAT extrai 11 diferentes atributos da série temporal, criando arquivos matriciais do que é chamado de métricas fenológicas. A figura 2 apresenta as 11 diferentes métricas geradas pelo TIMESAT.




Figura 2: Métricas extraídas pelo TIMESAT- A linha preta representa a série histórica original e a vermelha as linha após a aplicação do filtro. Os pontos a e b: início e fim do ciclo fenológico, c e d: o nível de 80% de distribuição dos dados, e se refere ao ponto mais alto, f é a amplitude sazonal e g a duração da estação. As integrais h e i mostram o efeito cumulativo de crescimento da vegetação. O ponto j é o valor mais baixo. O valor k é o meio do ciclo fenológico. Adaptado de Jönsson e Eklundh (2012).

Para a filtragem e suavização da série temporal NDVI MODIS, foi utilizado o método *Savitsky Golay* (SG) através do software TIMESAT 3.2, indicado como melhor método por

Chen et al., 2004. Posteriormente, foram as métricas fenológicas foram extraídas da série temporal suavizada, foram 11 métricas com valores relativos a informação de sazonalidade da vegetação. Os dados sazonais, foram extraídos para cada uma das estações de crescimento, representando 55 dados matriciais como resultado.

3.4 Coleta de dados de terreno e criação da base de aprendizagem

Além de dados de SR, foram utilizados dados da fazenda Gamada, URT (Unidade de Referência Tecnológica da EMBRAPA) e mais dados de terreno coletados via aplicações SatVeg, TerraClass e dados *Pangae*. Para tanto, primeiramente utilizou-se uma máscara feita pelo produto TerraClass, que indica o que é agricultura, pasto e floresta nativa. Após a máscara, foram selecionadas áreas para a identificação visual das séries temporais pela aplicação online SatVeg (EMBRAPA). Pelos dados do *Pangae*, foram realizadas álgebras entre os dados matriciais anuais, que configurasse uma intercalação entre diversos tipos de culturas e pasto em abordagem inter-anual. Com estes dados e informações do terreno, foi construída uma base de aprendizagem do algoritmo RF. Ao todo, foram selecionadas 197 amostras de 05 classes diferentes, sendo iLP (36 amostras), iLPF (1 amostra), Floresta (57 amostras), Pasto (60 amostras), Agricultura Intensificada, que representa duas culturas de verão (43 amostras). No local selecionado para o estudo, não foram encontradas mais amostras de iLPF além da fazenda Gamada, por este motivo a classe iLPF foi eliminada do modelo final. A figura 3 apresenta exemplo de curva padrão para cada uma das 5 classes extraída dos dados suavizados pelo método SG, representando o valor médio das parcelas da fazenda Gamada.




Figura 3: Perfis das amostras de cada classe na fazenda Gamada

3.5 Classificação *Random Forest*

Random Forest (RF) é uma técnica de aprendizado de máquina que gera uma infinidade de árvores de decisão aleatórias que são agregadas, para então gerar uma classificação (BREIMAN, 2001). Cada árvore de classificação (500 árvores em uma floresta típica) é construída de um conjunto amostrado aleatoriamente composto por aproximadamente um terço do conjunto completo de dados (CUTLER, 2007). Em estudos de classificação de uso e ocupação do solo, o classificador é considerado estável e relativamente eficiente, além de envolver poucos parâmetros definidos pelo usuário e mesmo assim gerar bons níveis gerais de

precisão (LAWRENCE, 2006). Dos resultados gerados através da abordagem de RF, a diminuição média na precisão (DMP) para uma variável permite avaliar a importância (o grau em que uma variável é discriminante) de cada variável usada para classificação. Quanto mais a precisão do RF diminui devido à exclusão de uma única variável, mais importante é essa variável. Consequentemente, valores mais altos de DPM indicam variáveis que são mais importantes para a classificação (CUTLER, 2007).

Como dados de entrada para o classificador RF, foram utilizados os dados originais do MODIS, assim como os dados das métricas fenológicas geradas a partir do software TIMESAT, que passaram anteriormente pelo processo de filtragem. Uma visão geral do procedimento é apresentada na figura 4.




Figura 4: Fluxo do trabalho.

As 11 métricas foram geradas utilizando o TIMESAT, onde o início e o fim da estação não foram inseridos, ou seja, não foram baseadas no conhecimento de campo, elas foram calculadas a partir do software com o valor de 10% da distribuição dos dados. Os dados de entrada foram suavizados e filtrados utilizando a técnica baseada na função SG. O TIMESAT possibilita a entrada de dados de qualidade, a fim de ponderar a suavização em pixels mais ou menos confiáveis. No caso da série MODIS, pode-se utilizar o produto *pixel reliability* para tal finalidade, porém esta opção não foi explorada.

4. Resultados e Discussão

É possível observar nítidas diferenças entre as respostas das 5 classes apresentadas na fig 02, começando pela floresta que tem níveis de valor NDVI acima de 0,8, chegando até 0,9, apresentando baixíssima amplitude. As áreas de agricultura intensificada apresentam dois picos e apresentam a maior amplitude, sendo o período de plantio e senescência/colheita a maior declividade, que não se apresenta da mesma forma nos sistemas iLP, que tem datas mais deslocadas e amplitude menor quando comparada com a agricultura intensificada. O Pasto apresenta baixa amplitude com ciclos longos e geralmente um pico somente.

Dois modelos de classificação RF foram aplicados, (i) utilizando somente as métricas fenológicas e (ii) utilizando as métricas e a série temporal original. O índice *kappa* para (i) foi

de 0,63 sendo que das 11 métricas, 09 apresentam potencial discriminatório entre classes. Neste resultado, as três variáveis que obtiveram maior valor DPM foram o ‘valor de pico’ (PEACK), ‘valor de base’ (BASEVALUE) e ‘amplitude’ (AMPLITUDE), respectivamente. Os menores valores DPM foram a ‘derivativa a esquerda’(LD), a ‘duração da estação’ (LOS) e a ‘derivativa a direita’ (RD), respectivamente. O algoritmo indica as variáveis que não tem representatividade para a discriminação entre as classes, que neste caso foram as duas últimas, ou seja, a ‘derivativa a direita’ (RD) e a ‘duração da estação’(LOS). A figura 5 apresenta os gráficos gerados pelo algoritmo.




Figura 5: A) Valores DPM das variáveis. B) Número de variáveis efetivamente discriminativas.

Devido ao baixo valor de acurácia encontrado, pretendeu-se realizar uma classificação utilizando os dois pacotes de dados para analisar se há alguma melhora na classificação e também para comparar os valores de DPM entre os dados brutos e das métricas geradas. O resultado melhorou consideravelmente, atingindo um valor de *kappa* de 0,89. Os valores de DPM apresentaram uma maior significância nas variáveis do NDVI bruto, excluindo praticamente todas as métricas fenológicas, considerando somente o ‘valor de pico’ (*peack*). A figura 6 apresenta os gráficos gerados pelo algoritmo para esta classificação.

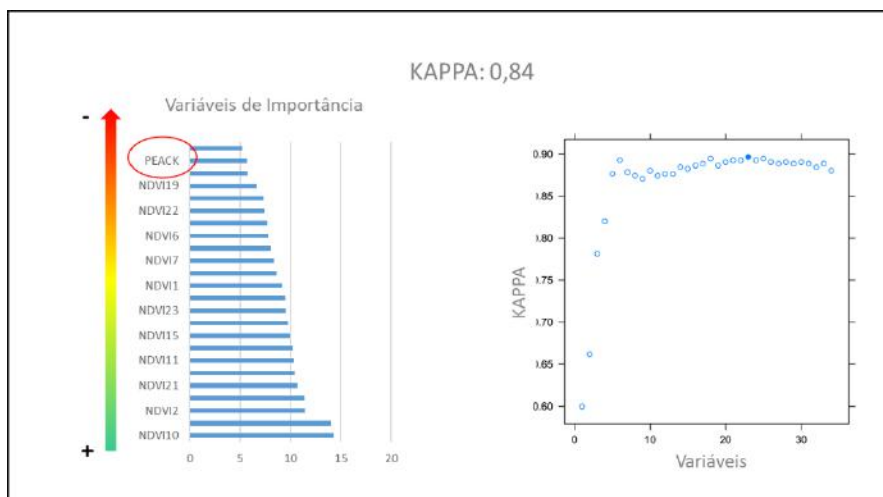


Figura 6: A) Valores DPM das variáveis. B) Número de variáveis efetivamente discriminativas

5. Conclusões e Sugestões

Os estudos atuais sobre a identificação e o mapeamento da dinâmica agrícola no estado do MT apresentam diversas abordagens no que se refere a técnicas e objetivos, porém a respeito de dados de sensores remotos óticos, ainda há uma grande tendência de esgotar a aplicação dos produtos MODIS, pois a região em que o estado se localiza é de alta frequência de nuvens, dificultando outros sensores óticos a atingir a temporalidade desejada. A limitação da resolução espacial não se caracteriza como um impeditivo para a aplicação dos estudos de agricultura neste estado, visto que, diferente da região centro-oeste, por exemplo, as glebas são geralmente acima de 10 ha.

Nossos resultados apontam que a utilização de métricas fenológicas não representaram melhora significativa na detecção de SI no MT. O resultado baseado nas métricas tem um valor considerado baixo quando comparado com o resultado do modelo que utiliza as séries originais. Quando integrada a série original com as métricas, a melhora no valor de kappa é alcançada, porém sem grande representatividade. Os resultados apontam que a utilização da técnica de classificação RF em abordagem multitemporal tem grande potencial para compor uma metodologia de monitoramento dos SI.

5. Agradecimentos

Os autores gostariam de reconhecer o apoio financeiro do Programa Capes / Cofecub para o Projeto GeoABC (Nº 845/15), assim como equipe da EMBRAPA, da fazenda Gamada e do CIRAD no laboratório UMR-TETIS (Unité Mixte de Recherche Territoires, Environnement, Télédétection et Information Spatiale) e a Embrapa Labex Europa pelo apoio metodológico e disponibilização de dados.

7. Referências

- Almeida, C., Coutinho, A., Esquerdo, J., Adami, M., Venturieri, A., Diniz, C., Dessay, N., Durieux, L., Gomes, A., 09 2016. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amazonica* 46, 291 – 302.
- Arvor D, Jonathan, M.; Meirelles, M. S. O. P.; Dubreuil, V.; Durieux, L. , 2011. Classification of MODIS EVI timeseries for crop mapping in the state of Mato Grosso, Brazil. *International Journal of Remote Sensing*, Vol. 32, Nº 22, pp. 7847 – 7871.
- Balbino, L.C., Barcellos, A.O., Stone, L.F. (Eds.), 2011 Marco Referencial Lavoura-Pecuária-Florestas. I. **EMBRAPA**.
- Bungenstab, D.J. (Ed.), 2012. Sistemas de Integração Lavoura-Pecuária-Floresta – A Produção Sustentável. ed. **EMBRAPA**, Brasília.
- Brasil. Ministério da Agricultura. Plano Setorial de mitigação e adaptação ao clima, **Livestock and Food Supply**. Brasília-DF: MAPA, 2011.
- Ministério da Ciência, **Tecnologia e Inovação. Estimativas anuais de emissões de gases de efeito estufa no Brasil**. Brasília-DF: MCTI, 2014.
- Breiman, L. **Machine Learning (2001) 45: 5**. Disponível: <https://doi.org/10.1023/A:1010933404324> [capturado em 10 agost., 2017].
- Câmara, G.; Picoli, M.; Simoes, R.; Maciel, A.; Carvalho, A.; Coutinho, A.; Esquerdo, J.; Antunes, J.; Begotti, R.; Arvor, D.. 2017. Land cover change maps for Mato Grosso State in Brazil: 2001-2016, links to files. **PANGAEA**, <https://doi.org/10.1594/PANGAEA.881291>.
- Carvalho, J.L.N., Raucci, G.S., Frazao, L.A., Cerri, E.C., Bernoux, M., Cerri, C.C., 2014. Crop-pasture rotation: a strategy to reduce soil greenhouse gases emissions in the Brazilian Cerrado. *Agric. Ecosyst. Environ.* 183 (1), 167–175.

Chen, Y., Dengsheng, L., Moran, M.; Batistella, M.; Dutra, L.V.; Sanches I. D.; Silva, R.F.B.; Huang, J.; Luiz, A.J.B.; Oliveira, M.A.F.. 2018. Mapping croplands, cropping patterns, and crop types using MODIS timeseries data. **Int J Appl Earth Obs Geoinformation**. V. 66 (2018) pp. 133-147.

Chen, J.; Jönsson, P.; Tamura, M.; Gu, Z.; Matsushita, B.; Eklundh, L. , 2004. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky–Golay filter. **Remote Sensing of Environment**, Vol. 91, Nº 3, pp. 332 – 344.

Cutler, D.R.; Edwards, T.C.; Beard, K.H.; Cutler, A.; Hess, K.T.; Gibson, J.; Lawler, J.J., 2007. Random forests for classification in ecology. **Ecology**, 88, 2783–2792.

Godfray, H.C.J., Beddington, J.R., Crute, I.R., Haddad, L., Lawrence, D., Muir, J.F., Pretty, J., Robinson, S., Thomas, S.M., Toulmin, C., 2010. Food security: the challenge of feeding 9 billion people. **Science** 327 (5967), 812–818.

Huang, C., Goward, S.N., Masek, J.G., Thomas, N., Zhu, Z., Vogelmann, J.E., 2010. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. **Remote Sens. Environ.** 114 (1), 183–198.

IMEA. Instituto Mato-Grossense de Economia Agropecuária. 2013. **Conhecimento em conjuntura e estrutura do agronegócio de Mato Grosso**. Cuiabá

Jönsson, P.; Eklundh, L., 2004 TIMESAT – a program for analyzing time-series of satellite sensor data. **Computers and Geosciences**, Vol. 30, Nº 8, pp. 833 – 845.

Kastens, J., Brown, J., Coutinho, A., Bishop, C., Esquerdo, J., 2017. Soy moratorium impacts on soybean and deforestation dynamics in Mato Grosso, Brazil. **PLOS ONE** 12 (4), e0176168.

Lawrence, R.L.; Wood, S.D.; Sheley, R.L., 2006. Mapping invasive plants using hyperspectral imagery and breiman cutler classifications (randomforest). **Remote Sens. Environ.** 100, 356–362.

Spera, S. A., Cohn, A. S., VanWey, L. K., Mustard, J. F., Rudorff, B. F., Rizzo, J., Adami, M., 2014. Recent cropping frequency, expansion, and abandonment in Mato Grosso, Brazil had selective land characteristics. **Environmental Research Letters** 9 (6), 064010.